

# 基于改进 PSO-WNN 的高频地波雷达 电离层杂波抑制方法\*

戴圆强, 尚 尚<sup>✉</sup>, 杨 童, 张先芝  
(江苏科技大学海洋学院 镇江 212100)

**摘要:** 高频地波雷达的海上目标探测能力与电离层杂波的抑制效果息息相关, 而电离层杂波的复杂性与变化多样性又为抑制带来了难题。为实现电离层杂波的抑制, 分析了电离层杂波的混沌特性, 在此基础上提出一种基于改进粒子群算法优化小波神经网络的抑制方法, 解决了粒子群算法易早熟和易陷入局部最优的缺点; 提出一种自适应概率变异的策略, 丰富了种群多样性, 使得整个迭代过程中粒子群能够跳出当前最优, 寻得全局最优。实测实验表明, 基于改进粒子群算法优化的小波神经网络 (PSO-WNN) 能够基本预测电离层杂波的数值, 进行电离层杂波的抑制, 有效改善了信噪比, 对电离层杂波的抑制研究具有重要意义。

**关键词:** 电离层杂波; 粒子群优化算法; 小波神经网络; 高频地波雷达; PSO-WNN

中图分类号: TN957.54 文献标识码: A 文章编号: CN11-1780(2022)03-0086-08

DOI: 10.12347/j.ycyk.20211228001

引用格式: 戴圆强, 尚尚, 杨童, 等. 基于改进 PSO-WNN 的高频地波雷达电离层杂波抑制方法[J]. 遥测遥控, 2022, 43(3): 86-93.

## Ionospheric clutter suppression method for HF ground wave radar based on improved PSO-WNN

DAI Yuanqiang, SHANG Shang, YANG Tong, ZHANG Xianzhi  
(Ocean College, Jiangsu University of Science and Technology, Zhenjiang 212100, China)

**Abstract:** The sea target detection ability of HF ground wave radar is closely related to the suppression effect of ionospheric clutter, and the complexity and diversity of ionospheric clutter bring difficulties to the suppression. In order to suppress ionospheric clutter, the chaotic characteristics of ionospheric clutter are analyzed. On this basis, a suppression method based on improved particle swarm optimization to optimize wavelet neural network is proposed, which solves the shortcomings of particle swarm optimization that it is easy to premature and fall into local optimization. An adaptive probability mutation strategy is proposed to enrich the population diversity, the particle swarm optimization can jump out of the current optimal and find the global optimal in the whole iterative process. The experimental results show that the wavelet neural network optimized based on the improved particle swarm optimization algorithm can basically predict the value of ionospheric clutter. After the suppression of ionospheric clutter, the signal-to-noise ratio is effectively improved, and the research on the suppression of ionospheric clutter is of great significance.

**Key words:** Ionospheric clutter; Particle swarm optimization algorithm; Wavelet neural network; HF ground wave radar; PSO-WNN

DOI: 10.12347/j.ycyk.20211228001

**Citation:** DAI Yuanqiang, SHANG Shang, YANG Tong, et al. Ionospheric clutter suppression method for HF ground wave radar based on improved PSO-WNN[J]. Journal of Telemetry, Tracking and Command, 2022, 43(3): 86-93.

\*基金项目: 国家自然科学基金项目 (61801196); 国防基础科研计划稳定支持专项项目 (JCKYS2020604SSJS010); 江苏省研究生科研与实践创新计划资助项目 (KYCX21\_3478、KYCX21\_3468)

✉通信作者: 尚尚 (shangshang@just.edu.cn)

收稿日期: 2021-12-28 收修改稿日期: 2022-01-11

## 引 言

当高频地波雷达探测海上目标及低空目标时,回波中掺杂着强度较高的电离层杂波,往往会淹没目标信号,这对雷达的探测性能有着极大的影响<sup>[1,2]</sup>。在这样的探测背景下,实现高效便捷的电离层杂波抑制是有必要的,这将大大提高雷达的探测性能。

在近些年的电离层杂波抑制方法的研究中,诸多学者采用了各种不同的方法去对电离层杂波进行处理,例如:特征值分解法<sup>[3]</sup>、小波分析法<sup>[4]</sup>、空域滤波<sup>[5,6]</sup>、极化滤波<sup>[7]</sup>等。空域滤波中典型的方法为自适应波束形成,通过让主瓣指向所需方向,让副瓣与杂波干扰分布自适应来抑制杂波,但其要求天线阵列口径较大,且对天线主瓣波束有一定要求,当目标与杂波处于同一波束内,会形成主瓣干扰,无法形成波束零陷;极化滤波技术利用目标和杂波在极化域的不同特征来进行滤波,但其会使系统变得更加复杂。

在近些年的研究中,由于电离层杂波的形态具有不稳定性<sup>[8]</sup>,且其变化具有复杂多样性,迄今为止还未有能适应各种情况的电离层杂波抑制方法。有学者希望从混沌理论出发,通过学习电离层杂波内在混沌特性,建立动力学模型来实现电离层杂波的抑制<sup>[9]</sup>。蓬勃发展的神经网络在处理非线性问题上有着得天独厚的优势,能够很好对时间序列进行预测。因此,本文提出了一种基于改进粒子群算法优化的小波神经网络(PSO-WNN),利用改进粒子群算法寻得小波神经网络的最优参数,建立了电离层杂波的训练以及预测模型,并最终实现对电离层杂波的抑制。

## 1 混沌性判别与相空间重构

高频地波雷达的电离层杂波是由发射能量逸散经电离层反射而形成的,电离层杂波的存在严重影响了高频地波雷达的探测效果。众所周知,诸多时间序列都是一种具有混沌特性的系统。本文从电离层杂波时间序列混沌特性的研究出发,进行电离层杂波的预测与抑制。

### 1.1 数据预处理

在具体处理电离层杂波时,通过学习待处理邻近距离单元的电离层杂波混沌特性,预测待处理具体单元的电离层杂波,从而进行抑制。因此,要先对邻近距离单元的雷达原始回波数据进行滤波处理,提取出电离层杂波。

采用基于特征值分解的办法对电离层杂波进行提取:

- ① 构造原始回波时域信号  $s(n), n=1, 2, 3, \dots, N$  的汉克尔矩阵  $\mathbf{H}$ 。
- ② 对原始回波数据的  $\mathbf{H}$  进行奇异值分解:

$$[\mathbf{U}, \mathbf{S}, \mathbf{V}] = \text{SVD}(\mathbf{H}) \quad (1)$$

式(1)中  $\mathbf{S}$  为特征值矩阵,  $\mathbf{U}$ 、 $\mathbf{V}$  包含了特征值所对应的左右特征向量。

- ③ 将地物杂波以及海杂波所对应的特征值与左右特征向量归零,重新构造汉克尔矩阵  $\mathbf{H}'$ :

$$\mathbf{H}' = \mathbf{U}'\mathbf{S}'\mathbf{V}' \quad (2)$$

运用重构后的汉克尔矩阵还原雷达回波数  $s'(n)$ 。

④ 对还原的回波数据  $s'(n)$  构建协方差矩阵  $\mathbf{R}_s$ , 并将其进行特征值分解得到  $n$  个特征值  $\lambda_1, \lambda_2, \dots, \lambda_n$  及所对应的特征向量  $\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_n$ , 通过特征值梯度准则划分杂波子空间与信号子空间, 计算得出特征值梯度大于平均梯度所对应的  $k$  个特征值, 并将其对应的特征向量所构成的子空间  $\text{span}\{\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_k\}$  认定为杂波子空间, 并将还原回波数据  $s'(n)$  在杂波子空间上进行投影, 得到提取的电离层杂波数据  $x(n)$ 。

### 1.2 混沌特性判别

关于时间序列混沌特性的判别有许多方法, 本文使用主分量分析法 PCA (Principal Component Analysis) 以及 Lyapunov 指数法进行混沌特性的判别。

在 PCA 分析法中利用电离层杂波时间序列, 并选取一定的嵌入维数  $d$  构成轨线矩阵  $\mathbf{X}_{l \times d}$ , 计算其协方差矩阵  $\mathbf{A}_{d \times d}$  的特征值。将特征值按大小排列  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$ , 则特征值的和为  $\gamma = \sum_{i=1}^d \lambda_i$ 。以指标  $i$

为  $X$  轴、 $\ln(\lambda_i/\gamma)$  为  $Y$  轴得到的图为主分量谱。噪声的主分量谱应是一条与  $X$  轴平行的直线, 混沌信号的主分量谱应是一条过定点且斜率为负的直线。

电离层杂波的主分量谱如图 1 所示。从图 1 中可以看出, 电离层杂波的主分量谱是一条过定点且斜率为负的近似直线, 这便可认为系统是一种混沌系统。

而根据 Lyaunov 指数法的计算方法得出 Lyaunov 指数  $\lambda = 0.1053 > 0$ , 则可判断系统长时间的行为对初始条件敏感, 从而认为系统的运动是一种混沌状态。

### 1.3 相空间重构

一个由混沌系统产生的轨迹经过一定时间的变化之后, 最终会呈现出一种有规律的运动, 但这种轨迹运动转化成时间序列时, 会呈现出杂乱的特征。相空间重构的目的就在于通过将时间序列扩展到更高维的空间, 从时间序列数据中提取和恢复系统原来的规律。

在相空间重构中, 时间延迟与嵌入维数这两个参数的选取是影响数据重构效果非常重要的因素。关于这两个参数的选取有许多的方法, 例如自相关与复自相关法、互信息量法等。在这几种方法中, 自相关函数法不适合处理非线性问题, 互信息法计算不便。实际计算中关联积分-关联维算法 (C-C 算法<sup>[10]</sup>) 更容易操作且计算量小, 对小数据组可靠, 效果与互信息法相当。因此, 本研究采用了 C-C 算法计算出时间延迟  $\tau$  与嵌入维数  $m$ 。

在电离层杂波的相空间重构中, 设滤除噪声后电离层杂波的一维时间序列为:

$$x(n), n = 1, 2, \dots, N \tag{3}$$

重构后的电离层杂波相空间为:

$$y(i) = [x_i, x_{i+\tau}, x_{i+2\tau}, \dots, x_{i+(m-1)\tau}] \tag{4}$$

根据 Takens 定理, 可将式 (4) 改写为:

$$x_{i+m\tau} = g(x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}) \tag{5}$$

观察式 (5) 可知, 通过已知采样时刻的采样值可非线性预测下一个未知时刻的采样值。

## 2 小波神经网络模型

由于混沌时间序列有着确定的非线性规律, 即在时间延迟状态空间中具有相关性, 一般的处理方法很难解析表达出这种内在规律, 而神经网络刚好具备这种处理非线性映射的强大能力, 因此可构建神经网络模型对电离层杂波进行预测抑制。

小波神经网络是一种以 BP 神经网络拓扑结构作为基础, 把小波基函数作为隐含层节点的传递函数, 信号前向传播的同时误差反向传播的神经网络。小波神经网络具有结构简单, 收敛速度快, 精度高的优点, 能够广泛应用于非线性函数的预测<sup>[11,12]</sup>。本文采用的小波神经网络的拓扑结构如图 2 所示。

小波神经网络的输入输出层的节点数根据具体情况自行进行设置, 根据混沌时间序列的预测方程, 可由  $m\tau$  个时刻的已知的采样数据经过非线性拟合, 预测得到下一个时刻的数据, 因此便设置输入节点

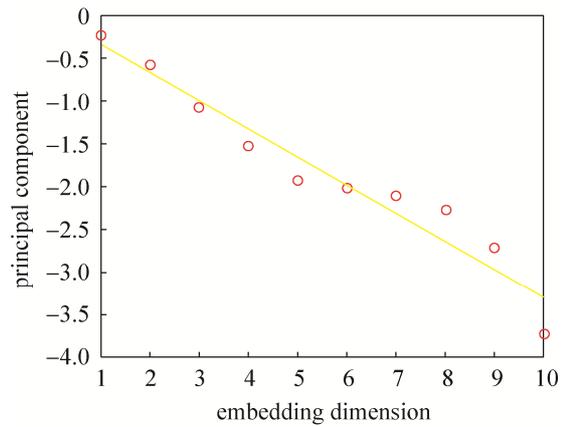


图 1 主分量谱图

Fig. 1 Principal component spectrum

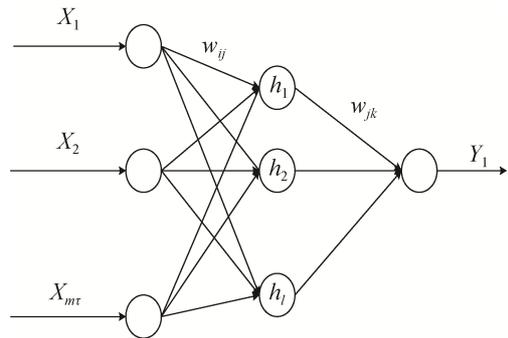


图 2 小波神经网络拓扑结构图

Fig. 2 Wavelet neural network topology diagram

数为  $m\tau$ ，输出节点数为 1。网络的输出值为：

$$Y(k) = \sum_{j=1}^l \omega_{jk} h(j), k=1 \tag{6}$$

其中， $\omega_{ij}$  为输入层和隐含层的连接权值， $\omega_{jk}$  为输入层和隐含层的连接权值， $h(j)$  为小波基函数即第  $j$  个隐含层节点的输出， $l$  为隐含层节点的个数。设神经网络的误差函数：

$$e = \sum_{i=1}^N (Y' - Y)^2 / N \tag{7}$$

其中， $N$  为训练样本数， $Y'$  为神经网络实际输出结果， $Y$  为网络的期望输出结果。

### 3 标准粒子群优化算法及改进方法

神经网络总体的预测性能受到设置的初始参数的影响，在初始参数设置中，若选取的参数不理想，在训练过程中便会导致神经网络收敛速度缓慢，并且容易陷入局部最优，影响最后预测模型的精度，严重影响电离层杂波的抑制效果。因此，为保证选取的网络初始参数最优，便引入粒子群优化算法 PSO (Particle Swarm Optimization) 并加以改进，增加小波神经网络预测模型的稳定性和精度<sup>[13-16]</sup>。

粒子群算法的寻优是模仿种群内捕食过程，种群中每一个个体都会搜索当前最靠近食物的那个个体的周边范围。在粒子群中的每一个粒子都代表一个解，用速度、位置和适应度值三项指标表示粒子的特征。粒子群随着迭代次数的增加，不断更新自身速度与位置，向全局最优靠近，最后寻得问题的最优解。

在每一次的迭代过程中，粒子群通过个体极值和全局极值更新自身的速度与位置，更新公式为：

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (P_{gd}^k - X_{id}^k) \tag{8}$$

$$X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1} \tag{9}$$

其中， $\omega$  为惯性权重； $k$  为当前迭代次数； $V_{id}$  为粒子的速度； $c_1$  与  $c_2$  是非负定值的学习因子，一般设置为 1.5； $r_1$  与  $r_2$  为 [0,1] 之间的随机数。

粒子群算法虽然收敛快，应用广泛，但其同时存在着容易早熟收敛、搜索精度低、后期迭代效率不高等缺点。Shi.Y 将惯性权重  $\omega$  设置为线性递减惯性权重， $\omega$  更新公式为：

$$\omega(k) = \omega_{start} - (\omega_{start} - \omega_{end}) \cdot (k / T_{max}) \tag{10}$$

其中，初始惯性权重  $\omega_{start}$  设置为 0.9，最终惯性权重  $\omega_{end}$  设置为 0.4， $k$  为当前迭代次数； $T_{max}$  为最大迭代次数。惯性权重的设置更好地平衡了全局搜索与局部搜索能力。但在粒子探索的过程中，粒子的种群空间被不断压缩，并仍未能解决粒子群算法会陷入局部最优的问题。为了解决这一问题，提出了一种自适应概率变异的改进方法，改进粒子群算法的流程如图 3 所示。

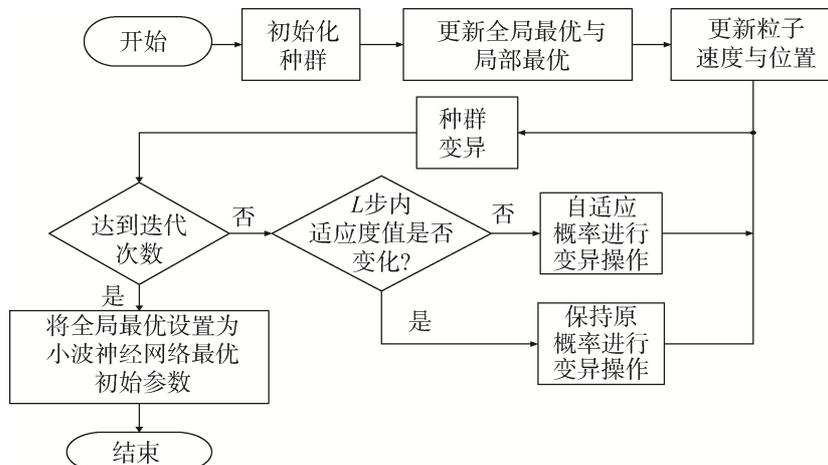


图 3 改进粒子群算法流程图

Fig. 3 Improved particle swarm optimization flowchart

在粒子更新完自身的速度与位置之后, 引入自适应概率变异, 自适应概率公式为:

$$p = 0.1 + (l - L)u(l - L) \frac{a(T_{\max} - k)}{T_{\max}} \quad (11)$$

其中, 0.1 为初始变异概率值,  $l$  表示适应度值未变化的迭代次数,  $L$  为设定好的阈值,  $a$  为概率参数, 是一非负常数,  $k$  为当前迭代次数,  $T_{\max}$  为最大迭代次数。在迭代过程中, 粒子以概率  $p$  发生变异。若适应度值未变化的迭代次数未超过阈值, 则变异概率为初始概率值; 若适应度值未变化的迭代次数超过阈值, 则变异概率会随迭代次数的增加而增加。

与此同时在适应度值产生变化时, 即  $l = 0$  时, 学习因子产生变化:

$$c_1 = c + 0.1rc \cdot u(|k - T_{\max}| / |k - T_{\max}|) \quad (12)$$

$$c_2 = c - 0.1rc \cdot u(|k - T_{\max}| / |k - T_{\max}|) \quad (13)$$

其中  $c$  为定值 1.5,  $r$  表示 (0,1) 的随机数,  $k$  为当前迭代次数,  $T_{\max}$  为最大迭代次数。

随着迭代过程的进行, 若粒子在迭代前期的全局搜索过程中适应度值未发生变化, 粒子将以较大的变异概率进行变异, 保证了较强的全局搜索能力; 在迭代后期中的局部搜索中, 粒子将以较小的概率进行变异, 在保证局部搜索能力的同时, 保持了粒子跳出局部最优的能力。

#### 4 建立电离层杂波预测抑制模型

电离层杂波预测模型的建立分以下三步:

① 通过 PSO 算法寻找网络最优初始参数, 需要寻优的参数包括输入层到隐含层的权重值、隐含层到输出层的权重值、小波基函数的平移因子以及尺度因子。算法的适应度函数设置为式 (7), 用粒子群的位置矢量表示 4 个参数, 通过粒子群算法在迭代过程中寻找最小神经网络误差即最优适应度值来得网络最优初始参数。

② 对小波神经网络进行训练, 选取待处理邻近单元的电离层杂波  $x(n), n = 1, 2, \dots, N$  作为输入数据, 根据式 (7) 将其重新构造造成  $(N - m\tau) \times m\tau$  维输入数据与  $(N - m\tau) \times 1$  维输出数据。通过  $N - m\tau$  组数据的训练, 小波神经网络通过不断更新自身参数, 最终学习电离层杂波的动力学规律, 具备映射其输入与输出的非线性关系的能力。

③ 将待处理单元的数据进行处理后, 作为网络的输入进行预测, 将得到的输出数据与原数据进行做差, 便得到抑制后的数据。

#### 5 实验测试与分析

在实验测试中, 采用频率为 3.7 MHz, 脉冲重复周期为 0.149 s 的实测雷达回波数据进行处理。取第 108 个距离单元的实测数据构造训练数据样本, 取第 109 个距离单元的实测数据作为待处理数据样本, 并对数据进行归一化处理, 以便加快数据处理速度。由 C-C 算法计算得到, 高频地波雷达实测电离层杂波第 108 个距离单元数据的时间延迟  $\tau = 3$ , 嵌入维数  $m = 4$ , 故网络输入层节点数设置为 12, 隐含层节点数设置为 4, 输出层节点数设置为 1, 并且设置粒子种群规模为 30, 最大迭代次数为 300。多次统计对比实验中发现,  $L$  与  $a$  的选择受到种群规模与最大迭代次数的影响, 在  $L$  的逐步增大的过程中发现粒子并不能够及时并有效跳出原有的种群空间; 而在  $a$  的逐渐增大的过程中, 会增加算法的复杂度, 导致运算速率降低, 而若  $a$  设置过小, 也并不能保证种群足够的多样性, 因此选择将  $L$  设置为 5,  $a$  设置为 0.05。在上述条件下进行实验, 粒子群算法效果如图 4 所示。

图 4 中 PSO 为标准方法, LDPSO 为线性递减惯性权重方法, ADPSO 为本研究所用自适应概率变异方法。从三种方法对比中看到, 虽然 LDPSO 方法比标准的 PSO 方法在收敛精度上有所提升, 但是仍然未寻找到全局最优的位置; 而在 ADPSO 方法中, 粒子能够从局部最优中跳出, 寻找全局最优。从图 4 中可

可以看出, ADPSO 方法在后期中仍然有能力跳出局部最优, 提升种群的多样性, 所以, ADPSO 性能表现为最优。

通过将改进 PSO 算法得出的最优参数设置到小波神经网络的初始化中, 对第 108 个距离单元的电离层杂波进行混沌特性学习, 对第 109 个距离单元的电离层杂波数据进行预测, 预测效果如图 5 所示。

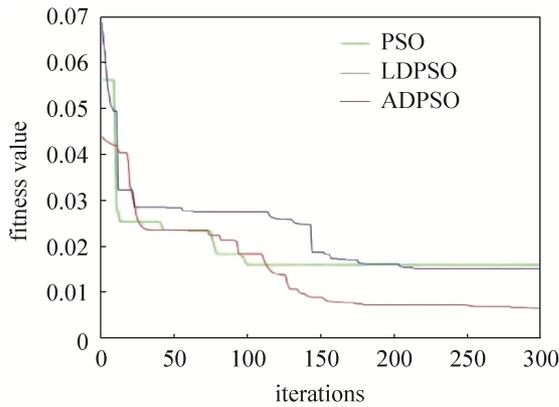


图 4 粒子群算法效果图

Fig. 4 Particle swarm algorithm renderings

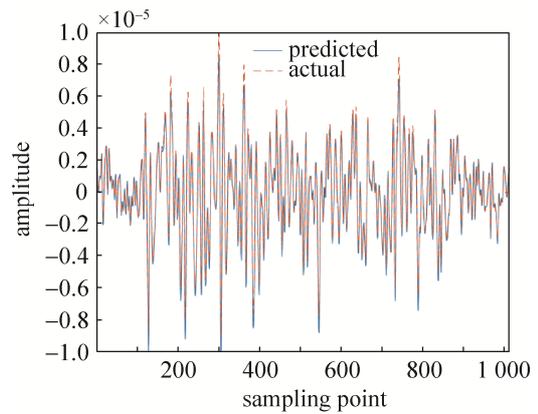
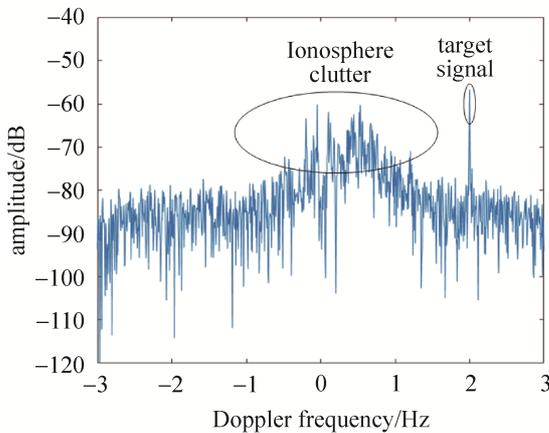


图 5 预测效果图

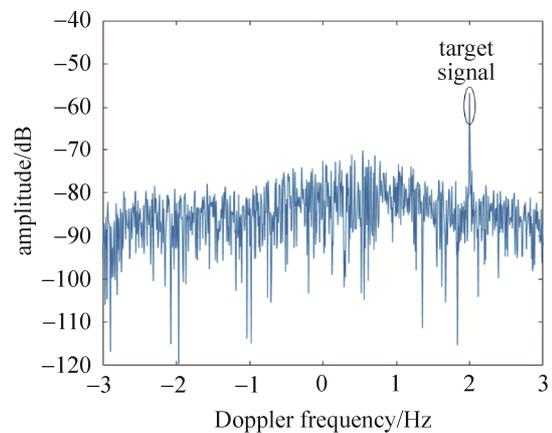
Fig. 5 Prediction renderings

为进一步分析抑制的效果, 在第 109 个距离单元的回波数据中加入了多普勒频率为 2 Hz 的目标信号, 从图 6 中可以看出经过抑制后目标信号未被抑制; 数据分析得出处理前杂噪比为 12.71 dB, 处理之后杂噪比为 4.76 dB, 降低了 7.95 dB。



(a) 抑制前多普勒谱

(a) Doppler spectrum before suppression



(b) 抑制后多普勒谱

(b) Doppler spectrum after suppression

图 6 加入目标信号第 109 距离单元杂波抑制前后多普勒谱

Fig. 6 Doppler spectrum before and after adding target signal 109th range unit clutter suppression

图 7 (a) 是加入了淹没在电离层杂波中多普勒频率为 0.5 Hz 的目标信号的多普勒谱, 图 7 (b) 为进行电离层杂波抑制得到的抑制后效果图。发现在利用本文方法进行电离层杂波抑制后, 保留了淹没在电离层杂波中的目标信号; 数据分析得出, 处理前信噪比为 9.49 dB, 处理之后信杂比为 15.09 dB, 提高了 5.60 dB。

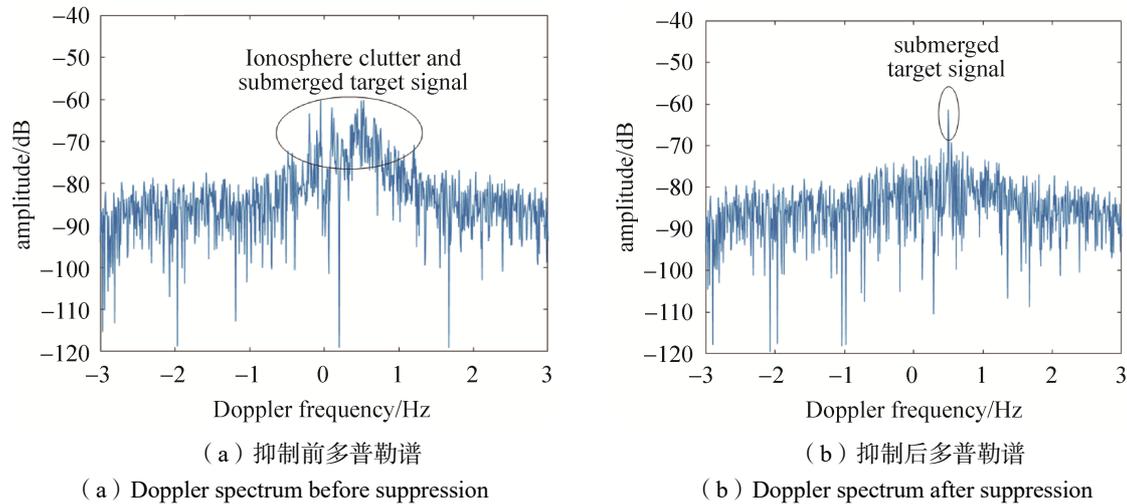


图 7 加入淹没目标信号第 109 距离单元杂波抑制前后多普勒谱

Fig. 7 Doppler spectrum before and after clutter suppression in the 109th range unit with submerged target signal

## 6 结束语

本文采用一种改进的粒子群算法优化小波神经网络, 通过训练小波神经网络学习电离层杂波的内在动力学规律, 实现电离层杂波的预测抑制。应用改进的粒子群算法对方法进行了优化, 提高了网络模型的稳定性和预测精度。从实测结果来看, 应用改进的粒子群算法与小波神经网络能够对电离层杂波进行预测与抑制, 有效改善了信噪比, 提升了雷达的目标检测性能。

## 参考文献

- [1] 李吉宁, 凡俊梅, 李雪, 等. 高频海态监测中几种电离层杂波特性及成因分析[J]. 电波科学学报, 2014, 29(2): 334–338, 384.  
LI Jining, FAN Junmei, LI Xue, et al. The characteristics and causes analysis of ionospheric clutter in HF surface wave radar[J]. Chinese Journal of Radio Science, 2014, 29(2): 334–338, 384.
- [2] 周浩, 文必洋, 吴世才. 高频地波雷达中电离层杂波的时频特征[J]. 电波科学学报, 2009, 24(3): 394–398.  
ZHOU Hao, WEN Biyang, WU Shicai. Time-frequency characteristics of the ionospheric clutters in high-frequency surface wave radars[J]. Chinese Journal of Radio Science, 2009, 24(3): 394–398.
- [3] 熊新农, 万显荣, 柯亨玉, 等. 基于时频分析的高频地波雷达电离层杂波抑制[J]. 系统工程与电子技术, 2008, 30(8): 13991402.  
XIONG Xinnong, WAN Xianrong, KE Hengyu, et al. Ionospheric clutter suppression in high frequency surface wave radar based on time-frequency analysis[J]. Systems Engineering and Electronics, 2008, 30(8): 13991402.
- [4] 熊新农, 万显荣, 柯亨玉, 等. 基于小波分析的高频地波雷达电离层杂波抑制[J]. 华中科技大学学报(自然科学版), 2008, 36(6): 77–80.  
XIONG Xinnong, WAN Xianrong, KE Hengyu, et al. Wavelet analysis-based suppression of ionospheric clutter in high frequency surface wave radar[J]. Journal of Huazhong University of Science and Technology(Nature Science Edition), 2008, 36(6): 77–80.
- [5] 尚尚, 张宁, 李杨, 等. 电离层杂波背景下 Constrained-MUSIC 算法在高频地波雷达中的应用[J]. 四川大学学报(工程科学版), 2012, 44(1): 144–148.  
SHANG Shang, ZHANG Ning, LI Yang, et al. Application of Constrained-MUSIC algorithm under the background of ionospheric clutter in HFSWR [J]. Journal of Sichuan University (Engineering Science Edition), 2012, 44(1): 144–148.
- [6] 皮小珊, 吴雄斌, 马克涛, 等. 组网高频地波雷达中电离层杂波分析及其抑制方法[J]. 科学技术与工程, 2016(1): 103–106, 125.  
PI Xiaoshan, WU Xiongbin, MA Ketao, et al. Ionosphere clutter analysis and suppression in HFSWR network[J]. Science

- Technology and Engineering, 2016(1): 103–106, 125.
- [7] 洪泓, 毛兴鹏, 果然, 等. 基于距离-多普勒域的电离层杂波极化抑制方法[J]. 系统工程与电子技术, 2014, 36(12): 2400–2405.
- [8] 孙孟彤. 高频地波雷达电离层杂波干扰特性研究[D]. 哈尔滨: 哈尔滨工业大学, 2013.
- [9] LYU ZHE, YU CHANGJUN, LIU AIJUN. Prediction method for ionospheric clutter suppression for HFSWR[J]. Electronics Letters, 2019, 55(15): 857–859.
- [10] H. S. KIM, R. EYKHOLT, J. D. SALAS. Nonlinear dynamics, delay times, and embedding windows[J]. Physica, D. Nonlinear phenomena, 1999, 127(1/2): 48–60.
- [11] 曹秀佳, 谷健, 马宁宁, 等. 基于粒子群优化小波神经网络模型的春玉米生育阶段干旱预测[J]. 灌溉排水学报, 2021, 40(3): 125–133.
- CAO Xiuja, GU Jian, MA Ningning, et al. Predicting droughts in growth season of spring maize with the wavelet neural networks using particle swarm optimization training[J]. Journal of Irrigation and Drainage, 2021, 40(3): 125–133.
- [12] 付莹莹, 宋李俊, 唐永晟, 等. 基于小波-神经网络的气候预测模型[J]. 探索科学, 2021(5): 201–202.
- [13] 吕振肃, 侯志荣. 自适应变异的粒子群优化算法[J]. 电子学报, 2004, 32(3): 416–420.
- LYU Zhensu, HOU Zhirong. Particle swarm optimization with adaptive mutation[J]. Acta Electronica Sinica, 2004, 32(3): 416–420.
- [14] 张选平, 杜玉平, 秦国强, 等. 一种动态改变惯性权的自适应粒子群算法[J]. 西安交通大学学报, 2005, 39(10): 1039–1042.
- ZHANG Xuanping, DU Yuping, QIN Guoqiang, et al. Adaptive particle swarm algorithm with dynamically changing inertia weight[J]. Journal of Xi'an Jiaotong University, 2005, 39(10): 1039–1042.
- [15] 胡堂清, 张旭秀, 曹晓月. 一种动态调整惯性权重的混合粒子群算法[J]. 电光与控制, 2020, 27(6): 16–21.
- HU Tangqing, ZHANG Xuxiu, CAO Xiaoyue. A hybrid particle swarm optimization with dynamic adjustment of inertial weight [J]. Electronics Optics & Control, 2020, 27(6): 16–21.
- [16] 李正明, 梁彩霞, 王满商. 基于 PSO-DBN 神经网络的光伏短期发电出力预测[J]. 电力系统保护与控制, 2020, 48(8): 149–154.
- LI Zhengming, LIANG Caixia, WANG Manshang. Short-term power generation output prediction based on a PSO-DBN neural network[J]. Power System Protection and Control, 2020, 48(8): 149–154.

#### [作者简介]

戴圆强 1997年生, 硕士研究生, 主要研究方向为弱目标检测和电离层杂波抑制。

尚 尚 1982年生, 副教授, 硕士生导师, 主要研究方向为雷达信号处理与杂波抑制方法研究。

杨 童 1996年生, 硕士研究生, 主要研究方向为弱目标检测和海杂波抑制。

张先芝 1998年生, 硕士研究生, 主要研究方向为弱目标检测和海杂波抑制。

(本文编辑: 傅 杰)